

II MRIの最新技術と未来展望—基礎編

3. 拡散MRIにおける ディープラーニングの活用 —信号値モデルのパラメータ推定を中心に

増谷 佳孝 / 佐々木 公 広島市立大学大学院情報科学研究科

拡散MRI (diffusion MRI : dMRI)¹⁾とは、異なる撮像設定による複数の拡散強調画像 (diffusion weighted image : DWI) を用いて水分子の拡散に基づく局所のさまざまな定量情報を得るための撮像法あるいはそのデータを指す。その定量情報の多くは信号値モデルのパラメータとして取得できるが、さまざまな信号値モデルから目的に応じたものを選択した後、計測されたDWIの画像信号値群にモデルをフィッティングする必要がある。近年、信号値モデルのパラメータを機械学習によって計算する手法が提案され、特にディープラーニングにより頑健かつ高速にパラメータを得ることができることが示され注目されている。

本稿では、機械学習、特にディープラーニングにより、dMRIパラメータの推定を行う手法の概要について実例を交えて紹介する。

信号値モデルと パラメータの推定

dMRIの信号値モデルとは、下記の式のように撮像設定値である移動検出傾斜磁場 (motion probing gradient : MPG) の強度 b と方向 \mathbf{g} 、および生体内の局所特徴を表すパラメータ p_1, p_2, \dots, p_N ($N \geq 1$) から画像信号値 S を計算することができるという一種の近似である。

$$S \cong f(b, \mathbf{g}, p_1, p_2, \dots, p_N)$$

注意すべき点は、局所すなわち各画素の位置によってこの式が成立し、MPGの設定は1回の撮像の画像全体で共通することから、パラメータの差異が計測された画像信号値の差異に反映されることである。dMRIにおけるパラメータ推定は、上記関数の出力である計測信号値から入力であるパラメータを推定するという一種の逆問題であるため、モデルに含まれるパラメータの数が複数であれば、異なる複数のMPGを用いた計測による複数の信号値が必要となる。dMRIの信号値モデルの代表的なものは、拡散テンソルイメージング (diffusion tensor imaging : DTI) であり、拡散テンソルに含まれる6つの独立成分がそのパラメータである。そのほかにも、拡散尖度イメージング (diffusional kurtosis imaging : DKI)、神経突起方位分散・密度イメージング (neurite orientation

dispersion and density imaging : NODDI) などがあり、それぞれ拡散尖度や線維の方位分散などをパラメータとして含む。

一般的なパラメータの推定法は以下のように、複数のMPGにより得た画像の信号値群 S_{mes} に対し、複数のパラメータ \mathbf{p} の関数であるモデル式から計算される同信号値群 S_{mdl} の誤差 $Err()$ が最小となるようなパラメータ $\hat{\mathbf{p}}$ を探索するフィッティングの最適化問題を解くことである。

$$\hat{\mathbf{p}} = \arg \min_{\mathbf{p}} Err(S_{mes}, S_{mdl}(\mathbf{p}))$$

ここでは、 N 個のパラメータ群を $\mathbf{p} = (p_1, \dots, p_N)$ とし、 M 種類のMPGで計測した画像信号値群を $S_{mes} = (S_{mes}(b_1, \mathbf{g}_1), \dots, S_{mes}(b_M, \mathbf{g}_M))$ 、同じMPGの組み合わせについてモデル式から計算される信号値群を $S_{mdl} = (S_{mdl}(b_1, \mathbf{g}_1, \mathbf{p}), \dots, S_{mdl}(b_M, \mathbf{g}_M, \mathbf{p}))$ としている。誤差の関数 $Err()$ の定義や解法についてはさまざまなものがあり、例えば、誤差関数として S_{mes} と S_{mdl} の各要素である信号値の差の二乗和を用いれば最小二乗法の問題となり、勾配法などの数値計算による最適化法が使用される。一般に、数値解法による問題として推定初期値への依存性や計算コストがしばしば挙げられる。特に、各画素の位置において反復計算で最適化問題を解くことが高コストにつながり、NODDIのようにモデル式が複雑になるほど無視できない問題となる。